

文章编号: 2095-2163(2022)01-0183-05

中图分类号: TP391.4

文献标志码: A

AMOLED 不良 MAP 自动缺陷定位方法研究

曾建风, 肖琨

(绵阳京东方光电科技有限公司, 四川 绵阳 621000)

摘要: AMOLED 生产工艺复杂, 在生产过程中容易受环境、化学气体、液体洁净度及设备工艺参数的影响, 在玻璃面板上形成大小不均的点状不良。当面板上出现大量不良点聚集时, 会导致该面板直接报废, 影响产品的最终良率。本文方法结合机器学习与图像处理技术, 可实现不良坐标点 MAP 图的在线智能分析。采用层次聚类算法对不良坐标点进行聚集分类, 对每类离散点簇采用 Alpha Shapes 算法提取其外轮廓点; 通过图像区域拟合算法, 拟合出每类点簇的最小包围图形区域, 并计算图形的 Hu 几何矩, 推导出各区域的区域特征(区域点密度、面积、区域的质心、区域方向、区域长宽比等), 并利用区域特征对图形区域进行筛选, 最终定位出不良点的目标聚集区域。实验证明, 本文方法可实现 MAP 图智能在线分析, 自动定位不良点聚集区, 可替代当前人工目检的方式, 保证检测质量, 降低工厂成本。

关键词: 映射图; Alpha Shapes; 层次聚类; Hu 矩; 特征提取

Research on auto MAP defect location algorithm of AMOLED

ZENG Jianfeng, XIAO Kun

(Mianyang BOE Optoelectronic Technology Co., Ltd, Mianyang Sichuan 621000, China)

[Abstract] Due to the complicated production process, AMOLED is easily influenced by the cleanliness of environment, chemical gas and liquid which will cause a large amount of uneven dot defects on glass during manufacturing. Concentrated region, that gathers a large amount of dot defects, will lead to final yield loss. As a result, detecting and locating the concentrated region timely is very important in AMOLED manufacturing field. Firstly, hierarchical clustering algorithm is used to divide the defects into classes with Euclidean distance threshold of defect points and alpha shapes algorithm is adopted to extract the outer contour points. Secondly, the smallest surrounding region of each class is fitted by interpolation algorithm, and then the region features is calculated by Hu moment algorithm, such as region density, centroid, orientation, area, length-width ration and etc. Finally, the candidate regions are filtered according to the feature value of destination regions. Experimental result shows that the proposed algorithm can realize intelligent analysis of defect MAP image, and locate the defect concentrated regions automatically which can replace manual inspection to guarantee quality and lower cost.

[Key words] MAP; alpha shapes; hierarchical clustering; Hu moment; feature extraction

0 引言

近年来,随着通讯技术的不断发展,5G 时代已经悄然进入人们的生活,并掀起了各行各业技术创新与变革的浪潮。不管是即将到来的 5G 时代还是未来的 6G 时代,显示技术都是信息化时代关键技术的核心,也是最前沿技术^[1]。

AMOLED 作为最新的一项显示技术,是由柔性显示材料制作而成的一种可变形的显示器件,具备可弯曲、低能耗、更优的显示质量、更长的使用寿命等优势,使其应用范围更加的广泛^[2-3]。但是,由于 AMOLED 工艺复杂,在生产过程中受空气洁净度、化学气体、液体及设备工艺参数的影响,会在面板上

形成大小不均的不良点。通常情况下,这些不良点不会导致最终产品不良,但具有聚集性的点簇除外。故需要对 AOI 检测出的不良点所生成的 MAP 图进行在线聚集性分析,找出造成良率损失的点位聚集区,供不良分析。

目前,MAP 图的不良点位聚集性分析均由人工目检完成,但由于人员主观性因素,检测质量和一致性无法保证。基于上述问题,本文提出了一种基于机器学习与图像处理技术,对 MAP 图进行在线智能分析方法,可迅速定位出 MAP 图中不良点的聚集区域,并根据区域的特征参数对聚集区域进行分析,筛选出造成良率损失的目标点簇区域,从而实现 MAP 图全自动在线分析。同时,本文所述的方法通过一

基金项目: 2020 年中国制造 2025 四川行动资金项目(GJ51074120201351310)。

作者简介: 曾建风(1987-),男,硕士,工程师,主要研究方向:图像处理、深度学习、数据分析等;肖琨(1993-),男,学士,工程师,主要研究方向:数据分析、图像处理。

收稿日期: 2021-10-22

系列量化的判断指标,降低人员主观判断带来的误判和漏判风险,节约人工成本,提高检测效率。

1 关键技术

2.1 不良 MAP 图合成

MAP 图即映射图,是指将一张面板上的不良点按照坐标映射为一张数字图像,用于可视化及后续的不良分析。在 AMOLED 的制造过程中,同一张面板会经过多个 AOI 的检测站点,AOI 设备会将面板上所有不良点 P_i 及坐标 (x_i, y_i) 上报文件系统。合成 MAP 就是将不良坐标点绘制在图像上的过程。

首先,创建玻璃面板与图像坐标系 $O_{glass} - XY$ 、 $O_{map} - XY$ 的二维映射关系 $M_{3 \times 3}$,其表达式为:

$$M_{3 \times 3} = \begin{pmatrix} R_{2 \times 2} & T_{2 \times 1} \\ \mathbf{0} & 1 \end{pmatrix} \quad (1)$$

其中, $R_{2 \times 2} = \begin{pmatrix} \cos \theta & -\sin \theta \\ \sin \theta & \cos \theta \end{pmatrix}$ 为旋转矩阵;

θ 为旋转角度; $T_{2 \times 1} = \begin{pmatrix} \hat{x}_0 \\ \hat{y}_0 \end{pmatrix}$ 为平移矩阵。

其后,对于玻璃面板的坐标系所有不良点 $p_i(x_i, y_i)$,经公式(2)变化后,可得到该点在图像坐标系的坐标 $p_i'(X_i, Y_i)$:

$$\begin{pmatrix} \hat{x}_i \\ \hat{y}_i \\ \hat{z}_i \end{pmatrix} = M_{3 \times 3} \begin{pmatrix} \hat{x}_i \\ \hat{y}_i \\ \hat{z}_i \end{pmatrix} \quad (2)$$

最后,将映射变换后的所有不良点绘制在一幅分辨率为 $M \times N$ 的图片上。其中, M 、 N 分别为基板的长度和宽度,单位为 mm。



图1 不良 MAP 聚集图

Fig.1 Defect map picture

2.2 聚集区域分割算法

本文提出的自动定位 MAP 图不良聚集区域算法,需要将满足聚集特征的区域提取出来,用于后续的图像分析使用,为此选择机器学习中常用的聚类算法完成。聚类是数据挖掘领域中常见的非监督学

习算法,其目的是将数据划分为类内相似度最大、类间相似度最小的族类^[4]。该算法在图像分析、模式识别、空间数据分析、经济学研究、生物工程等领域已得到广泛应用。

层次聚类算法分为凝聚(自底向上)和分裂(自顶向下)方法。凝聚方法是将每个对象作为单独的一个聚类,然后规则相近地合并相近的类,直到所有的对象合并到一个聚类中,或满足一定的终止条件为止。

本文采用最为经典的 AGNES 层次聚类算法,采用类簇间的欧式距离 D 作为聚类分析的度量标准,最小化类间样本距离作为聚类分析连接标准,将所有点簇 R 中,间距 $D \leq d$ 的点视作一类点簇。

$$D = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \quad (3)$$

其中, $p_i(x_i, y_i)$ 、 $p_j(x_j, y_j)$ 为任意两个类簇中相邻距离最近的两个点。

其聚类过程如下:

(1)将 MAP 图中 M 不良点视作 M 类簇,并计算出每个类簇之间的距离;

(2)随机找出距离最小且满足 $D \leq d$ 的两个点簇进行合并,得到 $M - 1$ 个类簇;

(3)计算 $M - 1$ 个类簇中相邻两个类簇之间的距离;

(4)重复步骤(2)、(3);

(5)最终得到满足 $D \leq d$ 条件的类簇数量 N ;

2.3 聚集区域拟合算法

Alpha Shapes 算法是从一堆无序的点簇中寻找边界,并通过算法重构其二维的区域图像^[5]。Alpha Shapes 在数学上有明显的定义,其原理为将一个半径为 α 的圆,在一个无序的点簇 S 外滚动; α 足够大时,圆就不会掉入点簇的内部,圆滚动的轨迹,就是点簇的边界线^[6]。所以在该算法中,半径 α 是唯一参数,其大小决定了边界区域的精细度。当 α 足够大时,则提取出来的边界线为点簇 S 的凸包;当 α 足够小时,点簇 S 的任意一个点都可能是边界点。廖中等^[7]提出了一种自适应 α -shapes 算法,使得滚动圆在边界滚动时能够自适应调节半径 α 的值,保证边界的精细度和完成性,其核心算法流程如下:

(1)将点云数据生成映射 MAP 图,得到一张分辨率为 $M \times N$ 大小的图片,像素值的大小等于该像素内点的数量(2.1 节已实现)。

(2)边界点判定。对每个像素点进行遍历,若该像素的值大于 0,且邻域点都大于 0,则该点为非边界点。

(3)对剩余的点进行 Alpha Shapes 判定:

$$m_{pq} = \sum_{(x,y) \in A} x^p y^q \quad (4)$$

$$M_{pq} = \sum_{(x,y) \in A} (x - x_0)^p (y - y_0)^q \quad (5)$$

其中: m_{pq} 为 $(p + q)$ 阶几何矩; M_{pq} 为 $(p + q)$ 阶几何中心矩; A 为目标区域; (x_0, y_0) 为区域 A 的几何中心。

(a)遍历剩余所有像素点 $p_i(x_i, y_i)$, 运用 K 最近邻域算法核心思想, 计算其 K 个最近邻域点, 并计算其欧氏距离的均值, 并设置为滚动圆的半径 α , 搜索所有距离该像素点距离小于 2α 的像素点, 形成新的点集 Q 。

本文中聚集区域的特征值包括: 点簇区域的面积 a 、点密度 ρ 、质心 $O(O_x, O_y)$ 、方向 θ 、长度 L 、宽度 W 、长宽比 r 等特征参数, 并运用这些参数对 MAP 图中不良点聚集区域进行自动筛选和定位。对于任一点簇区域 A_i , 上述特征值计算公式如下:

$$a = m_{00} \quad (6)$$

$$\rho = \frac{N}{a} \quad (7)$$

$$O_x = \frac{m_{10}}{a}, O_y = \frac{m_{01}}{a} \quad (8)$$

$$\theta = -0.5 \arctan\left(\frac{2M_{11}}{M_{02} - M_{20}}\right) \quad (9)$$

$$r = \frac{L}{W} \quad (10)$$

(b)任意 Q 中任意一个点 $p_j(x_j, y_j)$, 根据 p_i, p_j 及半径 α , 可以确定两个滚动圆及其圆心 O_1 和 O_2 。若 Q 中其它所有点到 O_1 和 O_2 距离均大于 α , 则该点 p_i 为边界点。

(c)若 Q 中没有满足条件(b)的点, 则该点 p_i 不是边界点。

(d)重复步骤(b)、(c), 直到找出所有边界点。

在上文中, 已得到满足聚类条件的 N 个类簇, 每一次类簇由一系列的离散点组成, 如图 2(a) 所示。本文涉及的算法需要将离散点拟合成多边形区域, 并运用图像处理技术处理计算其区域特征进行聚集区域筛选。对于离散点的区域拟合最常见的技术就是凸包拟合, 如图 2(b) 所示。图中离散点簇所围成的区域为凹形, 若采用凸包拟合算法得到的域明显不是点簇的真实形状。因此, 本文采用自适应 Alpha Shapes 算法来寻找点簇的边界点, 并将边界点连接起来形成点簇的聚集区域, 结果如图 2(c) 所示。

其中, N 表示区域 A_i 内不良点的数量, L, W 为 A_i 的最小外接矩形的长度和宽度。

3 算法流程及实验结果

本文将 AOI 上报的不良点映射成不良 MAP 图, 并通过层次聚类、自适应 Alpha Shapes、区域特征提取及筛选等算法, 自动定位出不良点的聚集区域, 详细算法流程如图 3 所示:

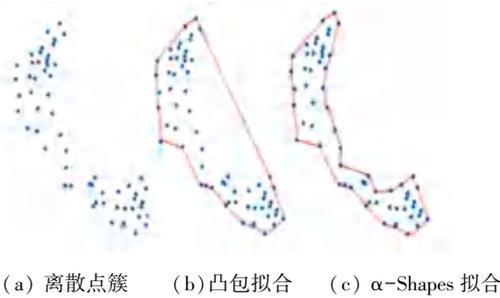


图 2 聚集区域图

Fig. 2 Concentrated region

2.4 聚集区域特征计算

在图像处理领域中, 对于图像目标区域的自动提取, 最常见的方法是: 先对图像进行阈值分割, 连通区域标记, 计算区域特征值, 再根据目标区域的特征, 自动定位出目标区域。Hu^[8] 于 1962 年提出了基于直角坐标的几何矩的概念, 并推导出一系列的具有尺度不变形、平移不变性和旋转不变形的变量^[9], 并广泛应用于图像识别、数据重建、图像压缩、运动图像分析等领域^[10]。

Hu 几何矩及中心距定义如下:

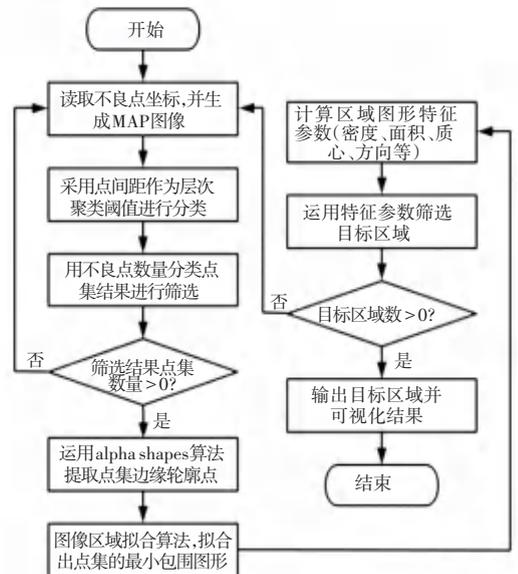
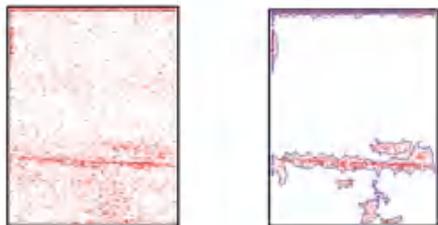


图 3 算法流程图

Fig. 3 Algorithm flow chart

(1) 读取 AOI 上报的单张/多张玻璃基板不良点坐标 (x_i, y_i) , 建立玻璃基板坐标系与图像坐标系之间的映射关系(公式(2)), 将基板坐标系中的不良点坐标转化为图像坐标系中坐标 (X_i, Y_i) 。实验中选择了生产过程中一个批次(28 张)的面板作为分析对象, 将这个批次面板上所有不良点坐标叠加到一起, 所形成的不良 MAP, 如图 4 所示。在该 MAP 图的顶部、右侧、中下部存在明显的不良点聚集区域。



(a) 不良 MAP (b) 目标区域轮廓

图 4 不良点聚集区域提取

Fig. 4 Defect concentrated region extraction

(2) 采用不良点间的欧式距离 D 作为聚类分析的先决条件, 将所有点簇 R 中间距 $D \leq d$ 的点视作一类点簇。具体采用机器学习领域的层次聚类的算法实现, 并运用 Single linkage(最小化类间样本距离)作为聚类分析连接标准, 得到最终的分类结果 $C = \{C_1, C_2, C_3, \dots, C_n\}, C_i \subseteq R$ 且 $n \geq 1$ 。

(3) 对于步骤(2)中的分类结果 C 进行筛选, 统计出每类点簇中不良点的数量 N , 剔除数量 $N \leq n$ 的点簇, 得到筛选后的结果 $C' = \{C'_1, C'_2, C'_3, \dots, C'_n\}, C' \subseteq C$ 。不良聚集区域一定是分类结果 C 中存在大量不良点的类别。由于本文采用层次聚类算法, 单个点或者少数的不良点也可能是一个独立的类别, 该类别不存在后续分析的价值, 通过本步骤可减少后续分析的点簇数量, 降低算法负载, 提升算

法的运行效率。

其中 n 为点簇中不良点的最小数量, 且 $n \geq 1$, 分类及筛选结果如图 4(a) 所示。

(4) 若步骤(3)筛选结果 $C' = \emptyset$, 则说明该 MAP 图不存在不良点聚集问题。相反, 则进一步进行分析。

(5) 对于 C' 中任一点簇 $C'_i = (p_1, p_2, \dots, p_n)$, 利用自适应 Alpha Shapes 算法, 从离散且无序的点簇 C'_i 中抽象出其直观的外部形状, 并得到外部形状轮廓点的集合 $C''_i = (p''_1, p''_2, \dots, p''_n), C''_i \subseteq C'_i$ 。由此可得到所有点簇 C' 的外轮廓点簇 C'' 。

(6) 采用图像处理领域的插值拟合技术, 根据任意点簇 C'_i 的轮廓点 C''_i 拟合出该点簇的最小包围图形区域 A_i , 由此可得到点簇 C' 相对应的图像区域集合 $A = \{A_1, A_2, \dots, A_7\}$, 如图 5(a) 所示。



(a) 拟合后目标区域 (b) 不良区域聚集图

图 5 目标区域筛选

Fig. 5 Objective region filtering

(7) 对任意图像区域 A_i , 先计算出该图形区域的 Hu 几何矩 $m_{i,j}$ 以及中心距 M_{ij} (公式(4)、(5)), 并推导出该图像区域的点密度 ρ 、面积 a 、质心 $O(O_x, O_y)$ 、方向 θ 、长度 L 、宽度 W 、长宽比 r 等特征参数(式(6)~式(10)), 并生成该区域的特征向量 $F = [\rho, a, O_x, O_y, \theta, L, W, r]^T$ 。图 5(a) 中各区域的特征值见表 1。其中, MAP 图的分辨率为 $1\ 500 \times 1\ 850$ pixel, 表中计算值的单位为 pixel。

表 1 区域特征

Tab. 1 Region features

区域	ρ	a	O_x	O_y	θ	L	W	r
A1	0.15	35 046	698.91	30.52	0.33	1 475	121	12.25
A2	0.19	11 698	36.64	316.21	88.52	56	381	0.15
A3	0.21	31 001	1 098.6	1 182.06	2.29	380	145	2.62
A4	0.18	170 168	779.88	1 311	1.43	1 468	388	3.78
A5	0.15	6 605	670.92	1 489.58	5.73	154	82	1.88
A6	0.16	30 331	918.29	1 689.29	66.19	287	374	0.77
A7	0.14	6 475	1 099.38	1 811.22	6.45	191	63	3.11